

# Classificação de Polaridade Orientada aos Alvos de Opinião em Comentários sobre Debate Político em Português

Eloize R. Marques Seno<sup>1</sup>, Fábio S. Igarashi Anno<sup>1</sup>,  
Lucas Lazarini<sup>1</sup>, Helena M. Caseli<sup>2</sup>

<sup>1</sup>Instituto Federal de São Paulo – São Carlos, SP

<sup>2</sup>Departamento de Ciência da Computação – Universidade Federal de São Carlos  
São Carlos, SP

eloize@ifsp.edu.br, {fabio.seyiji, lazarini.lucas}@aluno.ifsp.edu.br,

helenacaseli@ufscar.br

**Abstract.** *The internet and, especially social media, are fertile ground for publishing opinions on various subjects, products, and services. Traditionally, automatic analysis of opinions has been based on words that denote polarity or emotion. However, with the emergence of large language models like ChatGPT, the way in which we process text for subjective analysis has changed a lot. In this context, this paper aims to investigate the potential of ChatGPT – compared to a neural model for emotion identification in texts, and lexicon-based approaches – in polarity classification oriented towards opinion targets in comments on political debate in Portuguese.*

**Resumo.** *A internet e, em especial as mídias sociais, são um terreno fértil para a publicação de opiniões sobre os mais diversos assuntos, produtos e serviços. Tradicionalmente a análise automática de opiniões é realizada com base nas palavras que denotam alguma polaridade ou emoção. Contudo, com o surgimento dos grandes modelos de linguagem, como o ChatGPT, a maneira com a qual processamos textos para realizar análises subjetivas mudou bastante. Neste contexto, este artigo tem como foco investigar as potencialidades do ChatGPT – comparada com a de um modelo neural de identificação de emoções em textos e de abordagens baseadas em léxico – na classificação de polaridade orientada para os alvos de opinião em comentários sobre debate político em português.*

## 1. Introdução

O enorme volume de textos opinativos compartilhados nas mídias sociais como textos de avaliação de produtos em sites de comércio eletrônico, comentários de notícias sobre política, publicações em redes sociais, etc. tem despertado um interesse cada vez maior por algoritmos capazes de analisar a opinião pública. Essas opiniões e sentimentos têm grande apelo comercial e acadêmico, por influenciar nas tomadas de decisões dos indivíduos.

A análise de opiniões expressas em textos é o objeto de estudo da área de Análise de Sentimentos (AS), ou Mineração de Opiniões, uma subárea do Processamento de Linguagem Natural (PLN) que visa a utilização de recursos e ferramentas linguístico-computacionais para analisar automaticamente as opiniões e sentimentos de

peessoas com relação a entidades como produtos, serviços, organizações e indivíduos [Liu and Zhang 2012]. A AS se divide em duas tarefas principais: (i) mineração de opinião e (ii) mineração de emoção. A mineração de opinião está relacionada à detecção de polaridade (ou valência) associada à opinião do autor de uma postagem a respeito de uma entidade ou assunto em discussão, podendo ser positiva, negativa ou neutra. A mineração de emoção refere-se à identificação da emoção associada ao texto da postagem produzido pelo autor, como alegria, surpresa, raiva ou tristeza [Yadollahi et al. 2017]. Este estudo, mais especificamente, tem como foco a mineração de opinião (daqui em diante, classificação de polaridade) em textos de comentários do domínio político.

Tradicionalmente, a classificação de polaridade se refere ao sentimento geral conduzido por um documento ou sentença em particular. Contudo, as abordagens que analisam o sentimento geral de um documento/sentença podem apresentar limitações, quando um mesmo texto expressa opiniões sobre diferentes entidades, chamadas de alvos de opinião. Por exemplo, em um dos comentários presente no corpus utilizado neste estudo: “Portas muito bem, Sócrates a patinar.”, o sentimento em relação ao alvo “Portas” é positivo, enquanto o sentimento em relação ao alvo “Sócrates” é negativo. Para tratar adequadamente esses casos, é necessário considerar os diferentes alvos de opinião expressos em um mesmo comentário. É neste contexto que este trabalho se insere. Mais especificamente, o foco de interesse é a classificação de polaridade orientada para os alvos de opinião em textos políticos escritos em português. Ou seja, uma tarefa mais específica e desafiadora do que a análise geral do sentimento expresso pelo texto todo e menos refinada que a análise de sentimentos baseada em aspectos (por exemplo, [Assi et al. 2022, Schouten and Frasnica 2016]).

Para a classificação de polaridade orientada aos alvos de opinião em comentários sobre política, neste trabalho foram investigadas as potencialidades e limitações de uso do ChatGPT e de um modelo BERT de identificação de emoções, conhecido por GoEmotions, pré-treinado para o português [Hammes and Freitas 2021]. Além desses modelos, abordagens baseadas em léxicos de sentimentos – LIWC [Balage Filho et al. 2013] e SentiLex-PT [Carvalho and Silva 2015] – foram usadas como base de comparação. Os resultados de um experimento preliminar mostraram que o ChatGPT tem um potencial maior na realização da tarefa proposta, comparado aos demais modelos, apesar de não ser muito estável nas respostas. Até onde se sabe, este é o primeiro trabalho para o português a investigar o uso do ChatGPT na classificação de sentimento orientado ao alvo de opinião em textos em português.

O restante deste artigo está organizado da seguinte forma. A seção 2 apresenta de forma breve alguns trabalhos da literatura relacionados a este. Na seção 3 são apresentadas as estratégias investigadas para a classificação de sentimentos orientada aos alvos de opinião em textos, bem como o corpus de trabalho e os recursos e ferramentas linguístico-computacionais usados. Os resultados obtidos com cada estratégia são sumarizados na seção 4. Por fim, a seção 5 apresenta as principais conclusões deste trabalho.

## **2. Trabalhos relacionados**

Na literatura, os trabalhos relacionados à classificação de polaridade tem como foco a análise do sentimento geral de documentos ou sentenças (por exemplo, vide [França and Oliveira 2014], [Araújo et al. 2020] e [Capellaro and Caseli 2021]) ou de um

aspecto (característica) específico de uma entidade (por exemplo, [Assi et al. 2022] e [Schouten and Frasinicar 2016]).

Muitas abordagens distintas já foram investigadas [Liu and Zhang 2012, Pereira 2021, Hung and Alias 2023]. Dentre elas destacam-se as seguintes abordagens: (i) baseadas em conhecimento, que identificam palavras e expressões que carregam sentimentos a partir de léxicos construídos com base em *corpus* ou em recursos como o Wordnet (por exemplo, [Taboada et al. 2011] e [Akilandeswari and Jothi 2018]), (ii) baseadas em modelos tradicionais de aprendizado de máquina supervisionados ou não supervisionados (por exemplo, [Carvalho et al. 2017] e [Araújo et al. 2020]) e (iii) baseadas em aprendizado profundo [Zhang et al. 2018]. Abordagens híbridas combinando essas técnicas também são comuns [Appel et al. 2016].

Em [Carvalho et al. 2017], por exemplo, os autores compararam o desempenho de três algoritmos de aprendizado supervisionado (Naive Bayes, SVM e MaxEnt) e de três métodos de seleção de atributos (Qui Quadrado, CPD e CPPD) na classificação de polaridade em parágrafos de textos relacionados às eleições de 2014 no Brasil. A melhor performance, medida em termos de acurácia (cerca de 85%), foi obtida com o classificador MaxEnt usando o CPPD como método de seleção de atributos. Já em [Capellaro and Caseli 2021] os autores usaram modelos do tipo BERT, baseados em aprendizado profundo, na análise de polaridade e de tópicos em *tweets* relacionados às eleições de 2018 no Brasil. Usando um modelo pré-treinado para o português, a abordagem dos autores alcançou um *F1-score* de 96,6% na classificação da polaridade associada ao sentimento geral dos *tweets*.

Um trabalho que tem maior proximidade com esta pesquisa é o de [Assi et al. 2022]. Usando o modelo GoEmotions para o português [Hammes and Freitas 2021], os autores analisaram as emoções relacionadas a aspectos específicos de entidades em textos de revisão do setor de acomodação e, posteriormente, mapearam cada emoção para uma das três polaridades possíveis (positiva, negativa ou neutra), obtendo, assim, a classificação de polaridade para cada aspecto de uma entidade particular presente no texto. A estratégia dos autores alcançou um *F1-score* de 61,0%. De maneira similar a realizada por [Assi et al. 2022], neste trabalho o modelo pré-treinado por [Hammes and Freitas 2021] foi também usado para a identificação de emoções em comentários sobre debate político e, posteriormente, as emoções detectadas foram mapeadas para polaridades (conforme Seção 3). Porém, diferentemente de [Assi et al. 2022] nesta pesquisa a AS é realizada em nível de sentenças e não de aspectos.

### 3. Análise de sentimentos orientada aos alvos de opinião

Para a classificação de sentimentos (polaridade) orientada aos alvos de opinião em comentários sobre debate político em português, foi investigado o uso do ChatGPT e do modelo GoEmotions [Hammes and Freitas 2021]. A versão usada do ChatGPT se refere ao modelo GPT 3.5, disponível *online*<sup>1</sup> no período de 24 a 28 de junho de 2023. O GoEmotions, por sua vez, é um ajuste fino do BERTimbau [Souza et al. 2020] para a classificação de emoções em português. Esse modelo produz como saída uma lista de emoções ranqueadas de acordo com um valor probabilístico. São 27 emoções possíveis

<sup>1</sup>Disponível em: <https://chat.openai.com/>, versão de 24 de Maio, segundo a página. (Acessado em: 28/06/2023).

mais a emoção “neutra”. Quanto maior o valor associado à uma emoção, maior a probabilidade dela ocorrer no texto. Assim, para associar uma polaridade aos alvos de opinião, cada emoção foi mapeada para um sentimento positivo (1), negativo (-1) ou neutro (0), conforme apresentado na Tabela 1.

**Tabela 1. Mapeamento das emoções retornadas pelo GoEmotions para polaridades**

Polaridade	Emoções
-1 (negativo)	aborrecimento, constrangimento, decepção, desaprovação, luto, medo, nervosismo, nojo, raiva, remorso e tristeza
0 (neutro)	neutro, curiosidade, confusão, percepção e surpresa
1 (positivo)	admiração, alegria, alívio, aprovação, amor, desejo, diversão, entusiasmo, gratidão, orgulho, otimismo e zelo

Além dos modelos GPT e GoEmotions, também foram implementadas estratégias baseadas em léxicos de sentimentos, que serviram de base de comparação com os dois modelos neurais. Mais especificamente, foram usados os léxicos LIWC-PT<sup>2</sup> [Balage Filho et al. 2013] e SentiLex-PT<sup>3</sup> [Carvalho and Silva 2015]. O LIWC-PT é um léxico geral do português constituído por 127.149 instâncias organizadas em categorias. As categorias *posemo* e *negemo* indicam emoção (polaridade) positiva e negativa, respectivamente. Há também categorias para mineração de emoções como afeto, raiva, tristeza, etc., porém essas não foram exploradas neste estudo. O SentiLex-PT, por sua vez, foi concebido especificamente para a análise de sentimento e opinião sobre entidades humanas. Ele é composto por 7.014 lemas e 82.347 formas flexionadas organizadas em adjetivos, substantivos, verbos e expressões idiomáticas. Nos experimentos apresentados neste artigo, as expressões idiomáticas não foram usadas.

A subseção 3.1 apresenta uma descrição das abordagens investigadas neste trabalho e a subseção 3.2 descreve o corpus usado na avaliação de cada abordagem.

### 3.1. Descrição das abordagens de classificação de polaridade

A primeira abordagem é baseada no modelo GPT. Em linhas gerais, o ChatGPT recebe um texto de entrada (daqui em diante, *prompt*) com a descrição da tarefa a ser realizada pelo sistema e gera as saídas conforme solicitado. O desafio principal em lidar com o ChatGPT consiste em definir um *prompt* que gere as saídas exatamente como se espera para determinada tarefa. Essa “engenharia de *prompt*” não se mostrou uma tarefa simples, pois o sistema é bastante variável e por vezes até contraditório. Depois de algumas tentativas usando uma pequena amostra do corpus (10 sentenças), chegou-se ao seguinte *prompt*: “Dada a sentença <sentença> e o alvo sendo <alvo> qual a polaridade associada a ele, negativa (-1), positiva (1) ou neutra (0)?”, sendo <sentença> a sentença do comentário e <alvo> o alvo de opinião marcado no corpus (conforme explicado na Seção 3.2).

<sup>2</sup>Disponível em: <http://143.107.183.175:21380/portlex/index.php/pt/projetos/liwc>. Acesso em: 28 jun. 2023.

<sup>3</sup>Disponível em: <https://github.com/sillasgonzaga/lexiconPT>. Acesso em: 27 jun. 2023.

A segunda abordagem é baseada no GoEmotions. Para este modelo duas estratégias também foram investigadas: (BASE) a que considera o comentário como um todo para predição da emoção e (VIZ) a que considera apenas a região de vizinhança seguindo abordagem similar à de [Assi et al. 2022]. A polaridade atribuída é aquela resultante da combinação das top-3 melhores emoções retornadas com pontuação maior ou igual a 0,3, mesmo limiar adotado em [Assi et al. 2022].

Por fim, a terceira abordagem investigada faz uso de léxicos (LIWC-PT ou SentiLex-PT). Essa abordagem consistiu em atribuir ao alvo de opinião do comentário a polaridade resultante da soma das polaridades das palavras presentes no léxico. Neste sentido, duas estratégias de atribuição de polaridade foram investigadas: (BASE) uma que considera o comentário como um todo e (DEP) uma que considera apenas as palavras associadas ao alvo do comentário, já fornecido para cada sentença do corpus (Seção 3.2), via dependência sintática.<sup>4</sup> Assim, para cada palavra com polaridade presente no léxico (SentiLex-PT ou LIWC-PT) que também estava presente no comentário recuperou-se sua polaridade. Na estratégia BASE considerou-se como resultado a soma das polaridades de todas as palavras e no caso da estratégia DEP apenas as polaridades das palavras associadas ao alvo por alguma relação de dependência sintática.

### 3.2. Corpus de investigação

Como corpus de trabalho foi usado o SentiCorpus-PT [Carvalho et al. 2011]. A escolha desse corpus se deu pelo fato de que ele dispõe de anotações de polaridade de referência (isto é, realizada por humanos) e orientada aos alvos de opiniões presentes nos textos. O SentiCorpus-PT é composto por comentários sobre debates televisivos referentes às eleições de 2009 do Parlamento Português. A versão usada do corpus é composta de 1.082 comentários, totalizando 3.868 sentenças anotadas. Porém, neste estudo foram usadas apenas as primeiras 200 sentenças do corpus. Este número limitado se deve ao fato de que a versão livre do ChatGPT não dispõe de API e, portanto, o processamento do corpus é feito manualmente, ou seja, os comentários são fornecidos em pequenas quantidades como entrada para o sistema.

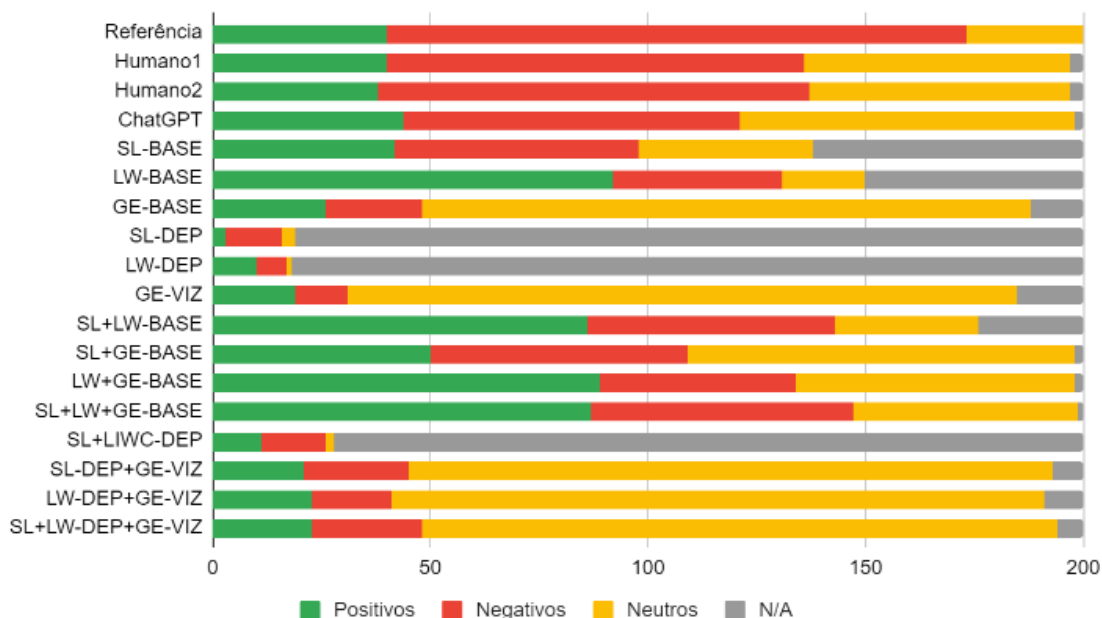
Cada sentença no corpus pode ter diferentes alvos de opinião. Os alvos de opinião são entidades humanas, nomeadamente políticos, organizações políticas (geralmente utilizadas para se referir aos seus membros), personalidades da mídia (por exemplo, jornalistas) ou usuários (comentadores). Cada sentença do corpus dispõe de anotações de polaridade variando de -2 (o valor negativo mais forte) até 2 (o valor positivo mais forte) e de alvos de opinião. Entretanto, nos experimentos realizados neste estudo a polaridade -2 foi mapeada para -1 (negativa) e a polaridade 2 foi mapeada para 1 (positiva).

## 4. Avaliação das estratégias

A avaliação das estratégias investigadas nesta pesquisa foi realizada tendo como referência a anotação manual de polaridades associadas aos alvos, fornecida pelo SentiCorpus-PT. Apesar do corpus dispor da anotação de polaridade orientada aos alvos de opiniões, optou-se por fazer uma nova anotação, a fim de verificar a concordância entre a anotação original feita por falantes do português europeu e a anotação realizada

<sup>4</sup>A dependência sintática neste caso foi gerada pelo modelo `pt_core_news_lg` do Spacy, disponível em: <https://spacy.io/models/pt>. Acesso em: 30 jun. 2023.

por falantes nativos do português na variante falada no Brasil. Os anotadores foram dois autores deste trabalho com larga experiência em anotação de corpus. A Figura 1 traz a distribuição de polaridade atribuída pela Referência (anotação original), pelos humanos falantes do português do Brasil e por cada uma das estratégias investigadas neste trabalho.



**Figura 1. Distribuição de classes da Referência (anotação original), dos brasileiros e das estratégias investigadas neste trabalho**

Como é possível notar na Figura 1, a anotação de Referência tem a maioria dos alvos associados à polaridade negativa. Os dois anotadores humanos (brasileiros) e o ChatGPT geraram uma distribuição de classes similar à da Referência, porém com uma quantidade maior de neutros do que ela. Acredita-se que o fato da anotação original ter sido realizada por anotadores que tinham um conhecimento do contexto do debate realizado em Portugal pode ter influenciado a atribuição de polaridades negativas mesmo quando o comentário em si não trazia explicitamente palavras ou sentimentos que denotassem essa polaridade.

O gráfico também traz a distribuição de classes para as abordagens baseadas em léxicos (SL e LW) e emoções (GE). Neste caso, nota-se que o SentiLex é mais balanceado, o LIWC tende para o positivo e o GoEmotions, para o neutro. As estratégias que limitam a associação de palavras de polaridade àquelas ligadas por alguma relação de dependência sintática ao alvo (DEP) levaram a um número muito grande de alvos não associados a polaridades (N/A); enquanto que a análise de emoção usando apenas a região de vizinhança do alvo (GE-VIZ) diminuiu a quantidade de alvos associados à polaridade negativa e aumentou a quantidade de alvos associados à polaridade neutra. Por fim, na parte inferior da figura são apresentados os valores para as combinações das estratégias, sendo que combinou-se as estratégias base (BASE) entre elas e as estratégias que consideram o alvo na determinação da polaridade, seja por dependência sintática (DEP) ou região de vizinhança (VIZ), entre elas.

A Tabela 2 traz os resultados da comparação das saídas geradas por cada estratégia

investigada neste artigo em comparação com a referência. Os resultados (porcentagens) são apresentados para cada classe (positiva, negativa e neutra) em termos de Precisão, Cobertura e F1-score. Seja  $c$  uma classe qualquer, a Precisão considera a quantidade de instâncias da classe  $c$  corretamente classificadas em relação ao total de instâncias classificadas como sendo da classe  $c$ . A Cobertura representa a quantidade de instâncias da classe  $c$  corretamente classificadas sobre o total de instâncias classificadas como classe  $c$  na anotação de referência. Por fim, F1-score representa a média harmônica entre a Precisão e a Cobertura. Após obter o F1-score de cada classe, calculamos a média aritmética entre os valores de F1-score das três classes, representada pela medida Macro-F1.

**Tabela 2. Resultados das estratégias investigadas neste trabalho em termos de Precisão (P), Cobertura (C), F1-score e Macro-F1 (M-F1)**

	Positiva			Negativa			Neutra			
	P	C	F1	P	C	F1	P	C	F1	M-F1
Humano 1	85,0	85,0	<b>85,0</b>	100,0	100,0	<b>100,0</b>	83,8	44,3	<b>57,9</b>	<b>82,1</b>
Humano 2	84,2	80,0	<b>85,0</b>	82,0	98,0	<b>73,0</b>	83,6	43,3	<b>96,3</b>	<b>75,1</b>
ChatGPT	<b>72,7</b>	80,0	<b>76,2</b>	<b>88,3</b>	51,1	<b>64,8</b>	23,4	66,7	<b>34,6</b>	<b>58,5</b>
SL-BASE	35,7	37,5	36,6	76,8	32,3	45,5	10,0	14,8	11,9	31,3
LW-BASE	26,0	60,0	36,4	64,1	18,8	29,0	5,3	3,7	4,3	23,3
GE-BASE	53,8	35,0	42,4	81,8	13,5	23,2	18,6	96,3	31,1	32,3
SL+LW-BASE	25,6	55,0	34,9	73,7	55,0	63,0	6,0	55,0	10,9	36,3
SL+GE-BASE	38,0	47,5	42,2	79,6	35,3	49,0	18,0	59,3	27,6	<b>39,6</b>
LW+GE-BASE	27,0	60,0	37,2	68,9	23,3	34,8	9,4	60,0	16,2	29,4
SL+LW+GE-BASE	27,6	60,0	37,8	73,3	33,1	45,6	7,7	60,0	13,6	32,3
SL-DEP	66,7	5,0	9,3	84,6	8,3	15,1	0,0	0,0	0,0	12,2
LW-DEP	60,0	15,0	24,0	85,7	4,5	8,6	85,7	0,0	0,0	10,9
GE-VIZ	68,4	32,5	44,0	83,3	7,5	13,8	16,2	92,6	27,6	28,5
SL+LW-DEP	<b>72,7</b>	20,0	31,4	<b>86,7</b>	9,8	17,6	<b>50,0</b>	3,7	6,9	18,6
SL-DEP+GE-VIZ	66,7	35,0	45,9	83,3	15,0	25,5	16,2	88,9	27,4	32,9
LW-DEP+GE-VIZ	60,9	35,0	44,5	88,9	12,0	21,2	16,0	88,9	27,1	30,9
SL+LW-DEP+GE-VIZ	65,2	37,5	47,6	88,0	16,5	27,8	16,4	88,9	27,7	34,4

Como é possível notar na Tabela 2, o ChatGPT apresentou o melhor desempenho global (i.e. 58,5% de Macro-F1), comparado a todas as estratégias avaliadas, ou seja, o modelo GPT foi o que mais se aproximou dos valores obtidos pelos humanos. O segundo melhor desempenho (ou seja, 39,6%) foi alcançado com a combinação do SentiLex-PT e o GoEmotions sem usar as dependências sintáticas (SL+GE-BASE). Os piores desempenhos foram obtidos pelas estratégias baseadas no SentiLex e LIWC usando as dependências sintáticas (i.e. SL-DEP, LW-DEP e SL+LW-DEP). Entretanto, a estratégia SL+LW-DEP, que combina os dois léxicos com as dependências sintáticas, alcançou um desempenho muito similar ao do ChatGPT em termos de Precisão na classificação de sentimentos positivos e negativos e obteve uma Precisão ainda superior à daquele modelo na classificação de sentimentos neutros. Porém, essa estratégia obteve um desempenho muito ruim em termos de Cobertura, o que prejudicou o seu desempenho global. A baixa cobertura apresentada pelas estratégias que usaram dependência sintática pode estar relacionada ao fato de que vários comentários no corpus não apresentam a estrutura

esperada de sujeito-verbo-objeto, o que pode ter impactado na qualidade da análise de dependência gerada, fazendo com que a palavra com polaridade não fosse corretamente associada ao alvo do comentário. Quando se observa o desempenho de cada estratégia em relação a cada classe de forma isolada, percebe-se que os melhores valores de *F1-score* para todas as classes foram alcançados com o modelo GPT, sendo que ele teve um desempenho melhor na classificação de sentimentos positivos do que negativos e neutros. De maneira geral, todas as estratégias tiveram um pior desempenho na classificação de sentimentos neutros, sendo que a estratégia SL-DEP, baseada no SentiLex e nas dependências sintáticas, não conseguiu classificar corretamente nenhuma das instâncias da classe neutra. Para esta estratégia, especificamente, o valor de Macro-F1 foi calculado considerando os *F1-scores* apenas das classes positiva e neutra.

**Tabela 3. Exemplo de comentário e as saídas retornadas pelas estratégias investigadas neste trabalho (IND representa as palavras de sentimento)**

**Comentário:** Foi de facto um debate cordato, civilizado, em que Jerónimo se mostrou um senhor e o Louçã meteu a viola no saco.

<b>Alvo:</b> Jerónimo				<b>Polaridade:</b> 1		
<b>SL-BASE</b> 1	<b>SL-IND</b> cordato, civilizado	<b>LW-BASE</b> -1	<b>LW-IND</b> debate, viola	<b>GE-BASE</b> 1	<b>GE-EMO</b> neutro, admiração	<b>CHATGPT</b>  1
<b>SL-DEP</b> N/A	<b>SL-IND</b> –	<b>LW-DEP</b> N/A	<b>LW-IND</b> –	<b>GE-VIZ</b> 0	<b>GE-EMO</b> neutro	

**Alvo:** Louçã

				<b>Polaridade:</b> -1		
<b>SL-BASE</b> 1	<b>SL-IND</b> cordato, civilizado	<b>LW-BASE</b> -1	<b>LW-IND</b> debate, viola	<b>GE-BASE</b> 1	<b>GE-EMO</b> neutro, admiração	<b>CHATGPT</b>  -1
<b>SL-DEP</b> N/A	<b>SL-IND</b> –	<b>LW-DEP</b> N/A	<b>LW-IND</b> –	<b>GE-VIZ</b> 0	<b>GE-EMO</b> neutro	

A título de ilustração a Tabela 3 traz um exemplo de comentário do corpus e as saídas retornadas pelas estratégias investigadas neste trabalho.

## 5. Conclusão

Este estudo avaliou as potencialidades do ChatGPT na tarefa de análise de polaridade orientada para os alvos de opinião em comentários do domínio político, comparando seu desempenho com o de outro modelo neural de classificação de emoções em textos e com o de estratégias baseadas em léxicos. Experimentos preliminares usando um conjunto de dados pequeno (200 comentários) mostraram que o ChatGPT tem potencial para identificar a polaridade associada a cada alvo de opinião em um comentário, sendo esta a estratégia que mais se aproxima do desempenho obtido por humanos na mesma tarefa. Contudo, cabe ressaltar que o uso do ChatGPT apresenta vários desafios como (i) a escolha do *prompt* de entrada apropriado com a descrição da tarefa a ser realizada pelo sistema, crucial para que ele entenda o que o usuário espera como saída, (ii) a variabilidade das respostas dadas para uma mesma entrada para usuários distintos e (iii) a necessidade de relizar o processo manualmente na versão gratuita.

Como trabalho futuro pretende-se avaliar um conjunto de dados maior e experimentar outros analisadores sintáticos de dependência, uma vez que os maiores valores de precisão foram alcançados pelas estratégias que usaram dependência sintática para atribuir o sentimento ao alvo. Porém, elas apresentaram uma cobertura muito baixa.



## Referências

- Akilandeswari, J. and Jothi, G. (2018). Sentiment classification of tweets with non-language features. *Procedia Computer Science*, 143:426–433. 8th International Conference on Advances in Computing Communications (ICACC-2018).
- Appel, O., Chiclana, F., Carter, J., and Fujita, H. (2016). A hybrid approach to the sentiment analysis problem at the sentence level. *Knowledge-Based Systems*, 108:110–124. New Avenues in Knowledge Bases for Natural Language Processing.
- Araújo, M., Pereira, A., and Benevenuto, F. (2020). A comparative study of machine translation for multilingual sentence-level sentiment analysis. *Information Sciences*, 512:1078–1102.
- Assi, F. M., Candido, G. B., dos Santos Silva, L. N., Silva, D. F., and Caseli, H. M. (2022). Ufscar’s team at ABSAPT 2022: using syntax, semantics and context for solving the tasks. In Montes-y-Gómez, M. and et al., editors, *Proceedings of the Iberian Languages Evaluation Forum (IberLEF 2022)*, volume 3202 of *CEUR Workshop Proceedings*. CEUR-WS.org.
- Balage Filho, P. P., Pardo, T. A. S., and Aluísio, S. M. (2013). An evaluation of the Brazilian Portuguese LIWC dictionary for sentiment analysis. In *Proceedings of the 9th Brazilian Symposium in Information and Human Language Technology*, pages 215–219.
- Capellaro, L. and Caseli, H. M. (2021). Análise de polaridade e de tópicos em tweets no domínio da política no Brasil. In *Anais do XIII Simpósio Brasileiro de Tecnologia da Informação e da Linguagem Humana*, pages 47–55, Porto Alegre, RS, Brasil. SBC.
- Carvalho, C. M. A., Nagano, H., and Barros, A. K. (2017). A comparative study for sentiment analysis on election Brazilian news. In *Proceedings of the 11th Brazilian Symposium in Information and Human Language Technology*, pages 103–111, Uberlândia, Brazil. Sociedade Brasileira de Computação.
- Carvalho, P., Sarmiento, L., Teixeira, J., and Silva, M. J. (2011). Liars and saviors in a sentiment annotated corpus of comments to political debates. In *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies*, pages 564–568, Portland, Oregon, USA. Association for Computational Linguistics.
- Carvalho, P. and Silva, M. (2015). SentiLex-PT: Principais características e potencialidades. *Linguística, Informática e Tradução: Mundos que se Cruzam, Oslo Studies in Language*, 7(1):425–438.
- França, T. and Oliveira, J. (2014). Análise de sentimento de tweets relacionados aos protestos que ocorreram no Brasil entre junho e agosto de 2013. In *Anais do III Brazilian Workshop on Social Network Analysis and Mining*, pages 128–139, Porto Alegre, RS, Brasil. SBC.
- Hammes, L. and Freitas, L. (2021). Utilizando BERTimbau para a classificação de emoções em português. In *Anais do XIII Simpósio Brasileiro de Tecnologia da Informação e da Linguagem Humana*, pages 56–63, Porto Alegre, RS, Brasil. SBC.

- Hung, L. and Alias, S. (2023). Beyond sentiment analysis: A review of recent trends in text based sentiment analysis and emotion detection. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 27:84–95.
- Liu, B. and Zhang, L. (2012). A survey of opinion mining and sentiment analysis. *Mining Text Data*, pages 415–463.
- Pereira, D. A. (2021). A survey of sentiment analysis in the portuguese language. *Artificial Intelligence Review*, 54(2):1087–1115.
- Schouten, K. and Frasincar, F. (2016). Survey on aspect-level sentiment analysis. *IEEE Transactions on Knowledge and Data Engineering*, 28(3):813–830.
- Souza, F., Nogueira, R., and Lotufo, R. (2020). BERTimbau: Pretrained BERT models for Brazilian portuguese. In Cerri, R. and Prati, R. C., editors, *Intelligent Systems*, pages 403–417, Cham. Springer International Publishing.
- Taboada, M., Brooke, J., Tofiloski, M., Voll, K., and Stede, M. (2011). Lexicon-based methods for sentiment analysis. *Computational Linguistics*, 37:267–307.
- Yadollahi, A., Shahraki, A. G., and Zaiane, O. R. (2017). Current state of text sentiment analysis from opinion to emotion mining. *ACM Computing Surveys*, 50(2):1–33.
- Zhang, L., Wang, S., and Liu, B. (2018). Deep learning for sentiment analysis : A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8.